

視界状況推定に向けたドライバの眼球運動の有効性の調査

大崎 敬太^{1,a)} 若園 裕太^{1,b)} 石田 繁巳² 白石 陽²

概要：視界不良は、交通事故の発生リスクを高める。視界不良による交通事故を防ぐためには、道路の視界状況を推定し、ドライバに提供することで、安全な経路選択を促すことが重要である。視界状況を推定する手法として、気象情報やカメラを用いた研究がある。しかし、これらの手法では道路ごとの推定や時間帯（昼・夜）に左右されない推定が難しい。これに対し、本研究ではドライバの眼球運動から視界状況を推定する手法を提案する。視線移動、注視、サッケードなどの眼球運動特徴量を用いて教師あり学習により視界状況を推定する。本稿では、ドライバの眼球運動が視界状況の推定に有効であるかの初期的検討として4種類の視界状況の推定に取り組んだ。直線道路走行時の眼球運動データから視界状況を推定した結果、F-measure 0.783 で4種類の視界状況を推定できることを確認した。

1. はじめに

交通事故の発生リスクを高める要因の1つとして、視界不良が挙げられる [1, 2]。視界不良は、気象条件や時間帯（昼・夜）、経路周辺に存在する建物などに影響されるため、交通事故の軽減に向けては各経路の視界状況をドライバに提供して安全な経路選択を促すことが重要である。

視界不良による交通事故を防ぐために、視界状況を推定する研究が行われている。視界状況を推定する研究として気象情報を用いた研究 [3] や車載カメラを用いた研究 [4–6] がある。気象情報を用いた手法では、建物の情報を考慮することができず、経路ごとの推定には適していない。車載カメラを用いた手法では、経路ごとの推定が可能であるが、夜間時の推定は難しい。

これに対し、本研究では、参加型センシング [7] によって網羅的にデータ収集を行う。参加型センシングのアプローチとして、ドライバモニタリングシステム（以下、DMS）を用いたデータ収集を想定する。DMSとは、ドライバの生体情報を把握することで安全に運転できるように支援するシステムである。DMSは、普及に向けて様々な取り組み [8, 9] が進んでおり、将来一般化することが予測される。

DMSを用いた視界状況推定手法として、本研究ではドライバの眼球運動を用いた視界状況推定手法を提案する。ドライバの眼球運動は、周囲の状況により変化することが報告されている。実際、文献 [10, 11] では、雨天時は晴天

時と比較して注視行動が変化すること、文献 [12] では、視認対象の増加によって眼球運動量が増加することが報告されている。視界不良時は、前方の見通しが悪化し、目標物を認識できる距離（以下、視程）も狭まるため、視界状況によって眼球運動が変化することが考えられる。そこで提案手法では、眼球運動の変化を分析することで視界状況を推定する。

本稿では、提案手法実現に向けた初期的検討として、視線移動、注視、サッケードなどの眼球運動特徴量を用いて教師あり学習により視界状況を推定する手法を示す。視界状況を悪化させる要因は複数存在するが、本稿では視界状況を悪化させる頻度をもっとも高い要因である「夜」と「雨天」の識別について取り組む。具体的には、眼球運動特徴量を用いて視界状況を晴天時・雨天時それぞれの昼・夜という4つに分類を行った。

提案手法の有効性を調査するため、晴天時と雨天時における昼夜の異なる視界状況下で走行したドライバの眼球運動から視界状況を推定する評価実験を行った。4クラス分類の推定精度を5分割交差検証によって評価した結果、F-measure が0.783 で視界状況を推定できることを確認した。以上の結果から、ドライバの眼球運動は、視界状況推定に有効であることが示唆された。

本稿の構成は以下の通りである。2章では視界状況推定とドライバの眼球運動に関する関連研究を述べ、3章で提案する視界状況推定手法を述べる。4章で初期的評価を述べ、5章でまとめとする。

2. 関連研究

関連研究として、まず、2.1節では視界状況推定に関する研究について述べる。次に、2.2節ではドライバの眼球運動に関する研究について述べる。

¹ 公立はこだて未来大学大学院システム情報科学研究科
Graduate School of Systems Information Science, Future University Hakodate

² 公立はこだて未来大学システム情報科学部
School of Systems Information Science, Future University Hakodate

a) g2122012@fun.ac.jp

b) g2121061@fun.ac.jp

2.1 視界状況推定に関する研究

視界状況推定に関する研究として、気象情報を用いた研究 [3] とカメラを用いた研究 [4-6] がある。

松沢ら [3] は、風速や降雪強度などの気象情報を用いて降雪時の視程を推定する手法を提案している。気象情報を用いることで、広域的な視程推定手法として十分な有効性を示している。しかし、風速や降雪強度は、山道の地形や建物の有無に影響を受けるため、経路ごとの局所的な推定は行われていない。

中村ら [4] は、固定カメラと車載カメラを用いた降雪時における視界状況推定手法を提案している。この手法では、コントラスト対比に着目し、視界状況を推定する手法を提案している。車載カメラを用いると、走行経路に沿った局所的な視界状況の推定は可能であるが、路面反射などの視程以外による視界不良や夜間時の推定を考慮していない。大久保ら [5] は、視程情報に基づいて吹雪の発生・未発生を分類するモデルを構築している。視程が 200m 以下である場合を吹雪発生、200m 以上の場合を吹雪未発生としている。CNN (Convolutional Neural Network) により分類した結果、F-measure は 0.8 以上の分類精度を示している。しかし、この研究では昼間帯の画像を用いているため、夜間が考慮されていない。森ら [6] は、車載カメラとミリ波レーダを用いて前方車両との距離と前方車両の輝度分布値を計測し、霧の濃さを 3 段階のクラスで分類する手法を提案している。この手法では、前方車両が存在しなければ霧の濃さを判定できないという問題がある。

2.2 ドライバの眼球運動に関する研究

ドライビングシミュレータを用いてドライバの眼球運動を分析した研究 [10-12] がある。Konstantopoulos ら [10] は、3つの条件（晴天時の昼・夜、雨天時）における運転時の被験者の眼球運動を計測し、分析を行った。その結果、晴天時の夜と雨天時は、晴天時の昼と比較して視線の移動が減少し、同じ箇所を見る時間が増加することを報告している。佐藤ら [11] は、運転中のドライバの注意散漫状態時の行動パターンを抽出するために、ヒヤリハット遭遇時の前後における視線と顔の向きの時系列変化に着目した注視と安全確認行動の分析を行った。その結果、集中状態と注意散漫状態ともに、晴れ・昼の条件では、広範囲を網羅的に確認していたが、雨・夜の条件では、中心を注視していた。村瀬ら [12] は、運転中のドライバの眼球運動を計測し、視認対象が多い交通状況では、眼球運動量が増加することを示した。豪雨や濃霧、吹雪などの悪天候時は、視界状況が悪化することによって視認できる対象が減るため、晴天時と悪天候時で眼球運動が変化すると考えられる。

以上のことから、ドライバの眼球運動は、視界状況によって変化すると考えられるため、視界状況の推定に有効であると考えられる。

3. 眼球運動を用いた視界状況推定手法

本章では、まず 3.1 節では提案手法の概要について述べ

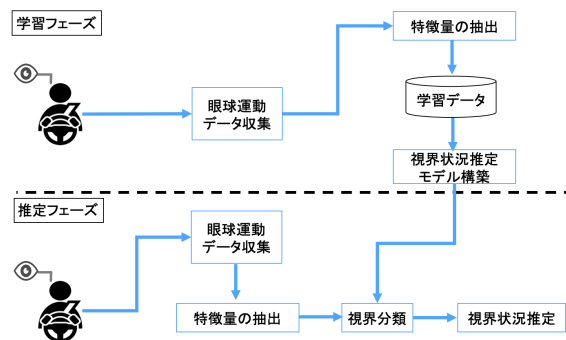



図 1: 提案手法の全体像



(a) 晴天時 (昼), (b) 晴天時 (夜)
(c) 雨天時 (昼), (d) 雨天時 (夜)

図 2: 対象とする視界状況

る。次に 3.2 節では、本稿の実験で対象とする視界状況について述べる。3.3 節以降では、眼球運動データの収集、対象とする眼球運動、予備調査、特微量の抽出、視界状況推定モデルの構築について述べる。

3.1 提案手法の概要

図 1 に視界状況推定手法の全体像を示す。本手法は、学習フェーズと推定フェーズの 2 つから構成される。

学習フェーズでは、眼球運動データを収集し、視界状況推定に用いる特微量を抽出する。抽出した特微量を正解ラベルとともに学習データとする。

構築した学習データを用いて、視界状況を推定するモデルを構築する。推定フェーズでは、走行中に収集した眼球運動データから特微量を抽出し、学習フェーズにて構築したモデルを用いて視界状況を推定する。

3.2 対象とする視界状況

本研究で対象とする視界状況は、晴天時 (昼)、晴天時 (夜)、雨天時 (昼)、雨天時 (夜) の 4 種類である。図 2 にそれぞれの視界状況におけるドライバ視点の画像の一例を示す。

3.3 眼球運動データの収集

眼球運動データの収集には、メガネ型アイトラッキングデバイスである Pupil Invisible [13] を使用する。本研究では、将来的に DMS でデータ収集することを想定している。そのため、DMS と同じデータを収集できるデバイスである Pupil Invisible を用いる。収集するデータは、ドライバの視点からの映像と眼球運動データである。図 3 に Pupil Invisible で収集している動画と動画内における座標を示す。Pupil Invisible が計測している眼球運動データは、動画の画面内における水平方向 (x 軸) と垂直方向 (y 軸) の座標値である。サンプリングレートは 200Hz である。座標値は動画内における座標を正規化したものである。




図 3: Pupil Invisible で計測している動画及び動画内での座標

3.4 対象とする眼球運動

提案手法で扱う眼球運動は、視線移動と注視、サッケードである。サッケードとは、ある点からある点へと視線を向ける際に行われる断続的な高速な眼球運動である [14, 15]。提案手法における各眼球運動の定義を以下に示す。

- 視線移動 (eye) : ある区間内における視点座標の変化量である。
- 注視 (fix) : 5 ミリ秒ごとで抽出した視点座標において、視点座標が一定以上の距離変化しなかったものである。
- サッケード (sac) : 5 ミリ秒ごとで抽出した視点座標において、視点座標が一定以上の距離変化したものである。

3.5 予備調査

予備調査として、各視界状況における眼球運動の変化について Pupil Invisible で取得したデータを分析した。

図 4 に晴天時 (昼) と雨天時 (昼) における走行中の視線移動データの一部を示す。横軸が経過時間 (sec)、縦軸が視点座標である。晴天時 (昼)、雨天時 (昼) ともに 10 秒間のデータである。青色の線が水平方向、赤色の線が垂直方向の視線の動きを示す。図 4 の晴天時 (昼) は雨天時 (昼) と比較して、水平方向において視線が大きく動いていることがわかる。

図 5 に図 4 のデータ時における注視の散布図を示す。横

表 1: 使用する特徴量

眼球運動	種類
視線移動 (eye)	水平方向 (基本統計量)
	垂直方向 (基本統計量)
注視 (fix)	水平方向 (基本統計量)
	垂直方向 (基本統計量)
	注視時間
サッケード (sac)	移動距離 (基本統計量)
	発生回数

軸が水平方向の視点座標、縦軸が垂直方向の視点座標である。散布図にプロットされた点の座標は、注視として抽出された座標群を平均化した座標である。晴天時 (昼) は、雨天時 (昼) と比較して水平方向の分布が大きく、雨天時 (昼) は晴天時 (昼) と比較して中心を見ていることが多いことがわかる。そのため、雨天時 (昼) では、前方の見通しが悪化することによって前方を注意して見ている可能性がある。また、雨天時は、サイドミラーが濡れることによって左右に視線を動かすことが減少することが考えられる。

図 6 に図 4 のデータ時におけるサッケードのヒストグラムを示す。横軸がサッケード距離で縦軸が頻度である。晴天時 (昼) の時のサッケード発生回数は、29 回で、雨天時 (昼) は 26 回である。晴天時 (昼) は、雨天時 (昼) と比較して、0.10 以上のサッケード距離が多く発生していることがわかる。そのため、雨天時 (昼) は晴天時 (昼) と比較して、小さいサッケードが多くなることが考えられる。

これらのことから、視界状況によって走行中の眼球運動に違いが現れると考えられる。

3.6 特徴量の抽出

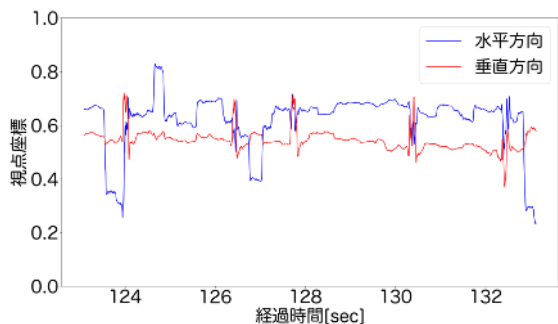
特徴量の抽出方法として、スライディングウィンドウを用いる。収集した眼球運動データを一定のウィンドウ幅で切り出し、切り出した眼球運動データから特徴量を抽出する。ウィンドウ幅 10 秒、オーバーラップ 50% として、ウィンドウごとに特徴量を抽出する。

表 1 に提案手法で用いる特徴量を示す。基本統計量は、平均値 (mean)、標準偏差 (std)、25 パーセンタイル (25p)、75 パーセンタイル (75p)、中央値 (median) の 5 種を算出する。


提案手法では、ウィンドウを切り出す前に停車中のデータを除去する。図 7 にある区間内における視線移動のグラフを示す。図 7 の黒枠は、信号待ちによる停車中の視線移動データである。停車中は信号や周辺の車両状況を確認するために視線を動かさずため走行時とは異なる視線移動となる。そのため、推定精度に影響を与えると考え、停車中のデータは除去する。

3.7 視界状況推定モデルの構築

3.6 節で説明した手順で抽出した特徴量を正解ラベルとともに学習データとする。学習データを用いて視界状況推定モデルを構築する。視界状況推定モデル構築にはランダムフォレストを用いる。




(a) 晴天時 (昼)



(b) 雨天時 (昼)


図 4: 視線移動の推移



(a) 晴天時 (昼)

(b) 雨天時 (昼)

図 5: 注視時の散布図



(a) 晴天時 (昼)

(b) 雨天時 (昼)

図 6: サッケードのヒストグラム




図 7: 走行中の視線移動

表 2: 実験条件

項目	内容
走行コースの距離	約 850m
走行コースの形状	直線道路
信号の数	1 個
対象とする視界状況	晴天時 (昼) 晴天時 (夜) 雨天時 (昼) 雨天時 (夜)
各視界状況のデータ数	200 個
被験者数	1 人
サンプリングレート	200Hz

4. 評価実験および考察

提案する視界状況推定手法の有効性を確認するため、ランダムフォレストを用いて視界状況推定モデルを構築し、モデルの精度評価を行った。4.1 節では、実験条件について述べる。4.2 節では、各視界状況下における眼球運動データの分析結果について述べる。4.3 節では、構築したモデルの精度評価実験について述べる。4.4 節では、実験結果についての考察を述べる。

4.1 実験条件

表 2 に実験条件を示す。図 8 に眼球運動データ収集時に走行したコースを示す。眼球運動データ収集に走行したコースは、約 850m の直線道路で信号の数は 1 つである。雨天におけるデータ収集時の 1 時間あたりの降水量は、0.5mm から 2.0mm であり、夜に関しては、0.5mm 以

下の降水量時のデータを含む。

4.2 精度評価

実験では、各眼球運動特徴の組み合わせごとに推定精度を交差検証にて評価した。評価指標として、F-measure をマクロ平均で算出した。表 3 に各眼球運動特徴の組み合わせにおける視界状況の推定精度を示す。

実験結果として、視線移動&注視&サッケードの眼球運動の組み合わせで構築したモデルが最も高い精度を示し、F-measure が 0.775 となった。サッケード単体で構築したモデルが最も低い精度を示し、F-measure が 0.458 となった。図 9 に視線移動&注視&サッケードの眼球運動の組み合わせで構築したモデルの混同行列を示し、表 4 にクラスごとの Precision, Recall, F-measure を示す。



図 8: 走行コース (出典: 国土地理院 [16])

表 3: 4 クラス分類精度評価結果

モデルに使用した眼球運動	次元数	F-measure
視線移動	10	0.722
注視	11	0.692
サッケード	6	0.458
視線移動 & 注視	21	0.765
視線移動 & サッケード	16	0.751
注視 & サッケード	17	0.711
視線移動 & 注視 & サッケード	27	0.775

表 4: クラスごとの Precision, Recall, F-measure

クラス	Precision	Recall	F-measure
晴天時 (昼)	0.813	0.785	0.799
雨天時 (昼)	0.772	0.845	0.807
晴天時 (夜)	0.760	0.730	0.745
雨天時 (夜)	0.760	0.745	0.752

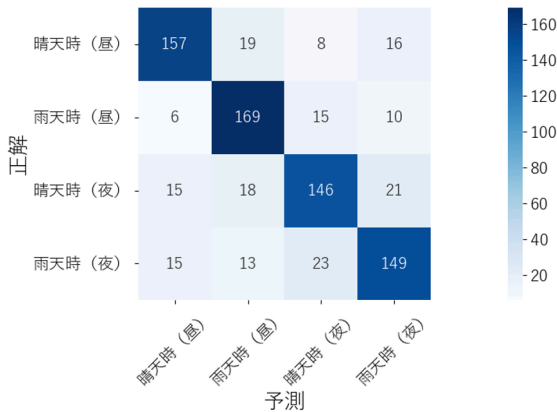


図 9: 混同行列

表 4, 図 9 の結果から, 晴天時 (昼) と雨天時 (昼) の精度は高いが, 晴天時 (夜) と雨天時 (夜) は互いに誤推定が多いことがわかる. そのため, 晴天時 (夜) と雨天時 (夜) でデータ傾向が似ていることが考えられる.

4.3 特徴量評価

視界状況推定に有効な特徴量を調査するため, 特徴量選




図 10: 特徴量次元数に対する F-measure

表 5: 特徴量が 9 次元の時の特徴量一覧

眼球運動	特徴量
視線移動 (eye)	eye-median-x
	eye-75p-x
	eye-std-x
	eye-median-y
	eye-mean-y
	eye-std-y
注視 (fix)	fix-std-y
	fix-75p-y
	fix-median-y

択手法の 1 つである再帰的特徴量削減を用いて特徴量選択を行った. 再帰的特徴量削減とは, 全ての特徴量からモデルを構築し, 重要度が低い特徴量を 1 つずつ減らしていく手法である. 特徴量の重要度は, ランダムフォレストによる変数重要度を用いて算出した. 提案手法で用いた特徴量は 27 次元であり, 1 次元になるまで特徴量を削減した.

図 10 に再帰的特徴量削減の結果を示す. 横軸が次元数, 縦軸が F-measure である. 図 10 から, 特徴量削減に伴い F-measure は 0.775 から始まり上昇と下降を繰り返し, 18 次元まで特徴量を削減した時に F-measure が 0.783 となり, 最も高い精度を示した. 18 次元までに削減された特徴量は, 視線移動から抽出した特徴量が 1 つ, 注視から 4 つ, サッケードから 4 つである. また, 特徴量を 8 次元まで削減した時, F-measure が大幅に低下していることがわかる. このことから, 特徴量を 9 次元まで削減した時に使用している特徴量が視界状況推定に有効であることが考えられる. 表 5 に, 特徴量が 9 次元の時に使用した特徴量を示す.

表 5 から, サッケードの特徴量は全て削除されており, サッケードは視界状況推定に有効な特徴量ではないことがわかる. また, 垂直方向における注視の特徴量と視線移動の特徴量が有効であることがわかる.

4.4 考察

ランダムフォレストによる各眼球運動特徴の組み合わせごとに 5-分割交差検証を行った結果, 視線移動&注視&サッケードの眼球運動の組み合わせで構築したモデルが最も高い精度を示し, F-measure が 0.775 となった. 図 9 より, 晴天時 (夜) を雨天時 (夜) と誤検知が多かった理由と

しては、夜間時は、昼間時と比較して、視野が狭くなるため、切り出したウィンドウによっては、データの傾向が近くなったことが考えられる。また、雨天時（夜）のデータには、1時間あたりの雨量が0.5mm以下の状況で収集したデータが含まれている。そのため、前方の見通しの悪化による眼球運動への影響が少なく、晴天時（夜）に近い視界状況であったことも原因であると考えられる。本稿で述べた実験では、雨量を区別せず平均化しているため、雨量ごとの眼球運動を調査し、提案手法の改善を行う必要がある。

表3より、サッケード単体で構築したモデルが最も低い精度を示し、F-measureが0.458となった。また、図10で最も精度が高かった時の特徴量に sac-mean と sac-75p が含まれていた。サッケードは、単体での推定精度は低いが、他の眼球運動の特徴量と組み合わせた時、精度向上に寄与することがわかった。理由としては、晴天時は雨天時と比較して視界が広いいため、移動距離が長いサッケードが発生しやすいことが考えられる。しかし、サッケードは、ドライバが確認しなければならない対象物の増減によって変化すると考えられるため、視界状況に加えて交通状況の影響も受ける。そのため、サッケード単体では視界状況の違いを把握することが難しく、精度が低くなったと考えられる。表1より、27次元から9次元までの特徴量次元数では、精度に大きな変化はなかった。そのため、推定精度に影響しない特徴量を多く含んでいることが考えられる。

特徴量の検討にあたり、サッケードの抽出方法についてさらに検討する必要がある。理由として、晴天時（昼）といった比較的、視界が良好な状況では、移動距離が長いサッケードが多くなる。しかし、視界が狭まる視界不良時では、移動距離が短いサッケードが多くなることが考えられる。そのため、サッケードを抽出する際に指定している距離を短くすることで、より詳細に視界状況を把握することができると思われる。

5. おわりに

本稿では、ドライバの眼球運動を用いて視界状況を推定する手法の初期的検討を行った。評価実験では、ランダムフォレストを用いて、各眼球運動の組み合わせごとにモデルを構築し、晴天時と雨天時における昼夜の4クラス分類を行い、5-分割交差検証と再帰的特徴量削減による評価を行った。その結果、視線移動&注視&サッケードの眼球運動の組み合わせで構築したモデルが最も高い精度を示し、F-measureが0.783となった。本結果から、ドライバの眼球運動が視界状況の推定に有効であることが示唆された。

今後の課題として2つ挙げられる。

1つ目は、より詳細な視界状況の定義、推定である。本稿では、視界状況が4つに分類できるものとして視界状況の推定を行った。しかし、視界状況は1つの天候によっても様々である。そこで今後は、視界状況を雨量や視程などから、より詳細に定義し、推定することを目指す。

2つ目は、個人差を考慮した推定手法の検討である。本研究では参加型センシングによる網羅的なデータ収集を想

定している。運転中の眼球運動には個人差があると考えられるため、複数の被験者の眼球運動データを収集して分析する必要がある。

謝辞 本稿で示した研究の一部は、JSPS 科研費 JP20K11793 の助成を受けたものである。

参考文献

- [1] 矢野伸裕, 横関俊也, 森健二: 降雨による視認性低下が高速道路走行時の認知反応に及ぼす影響, 交通工学論文集, Vol.1, No.1, pp.1-10 (2015).
- [2] 竹内政夫: 冬の視界不良事故について-交通事故統計からみる発生構造-, 日本雪氷学会北海道支部機関誌, No.33, pp.35-38 (2014).
- [3] 松沢勝, 竹内政夫: 気象条件から視程を推定する手法の研究, 日本雪氷学会誌, Vol.64, No.1, pp.77-85 (2002).
- [4] 中村裕貴, 萩原亨, 永田泰浩: 固定カメラと車載カメラによる冬期道路管理向け視界情報評価に関する研究, 土木学会論文集 D3, Vol.75, No.6, pp.599-607 (2020).
- [5] 大久保幸治, 高橋丞二, 武知洋太, 櫻井俊光, 國分徹哉: AI を利用した車載カメラによる吹雪検知の可能性について, 国立研究開発法人土木研究所寒地土木研究所, 寒地土木研究所月報, No.798, pp. 32-37 (2019).
- [6] 森健史, 高橋友和, 井手一郎, 村瀬洋, 宮原孝行, 玉津幸政: 車載カメラ映像とミリ波レーダデータによる霧の濃さの判定, 電子情報通信学会技術研究報告, Vol.106, No.605, pp.85-90 (2007).
- [7] Burke, J., Estrin, D., Hansen, M., Parker, A., Nithya., R, Rebbly, S and Srivastava, M.: Participatory Sensing, Workshop on World-Sensor-Web (WSW): Mobile Device Centric Sensor Networks and Applications, pp1-6 (2006).
- [8] 後藤誠二, 峯岸由佳, 山本直樹, 森谷貴行, 中村創, 片山翔太: カメラを用いたドライバー・モニタリングの開発, マツダ技報, No.36, pp. 130-135 (2019).
- [9] 岡田直之, 杉江哲, 濱上斉, 藤岡稔, 山本晋: ドライバ状態推定に向けた視線検出技術の開発, 富士通テン技報, Vol.33, No.1, pp.3-8 (2016).
- [10] Konstantopoulos, P. Chapman, P and Crundall, D.Driver's Visual Attention as a Function of Driving Experience and Visibility. Using a Driving Simulator to Explore Driver's Eye Movements in Day, Night and Rain Driving, Accident Analysis & Prevention, Vol.42, No.3, pp.827-834 (2010).
- [11] 佐藤和人, 勝保健太郎, 伊藤桃代, 間所洋和, 門脇さくら: 注意散漫状態の検出に向けたドライバ身体情報の分析, 情報処理学会情報科学技術フォーラム講演論文, Vol.14, No.3, pp.35-42 (2015).
- [12] 村瀬健二, 武田雄策, 原利宏, 金子寛彦: 自動車運転時の周辺対象認知における頭部と眼球運動, 日本バーチャルリアリティ学会論文誌, Vol. 23, No.3, pp.207-216 (2018).
- [13] Tonsen, M., Baumann, C., and Dierkes, K.: A High-Level Description and Performance Evaluation of Pupil Invisible, arXiv preprint arXiv:2009.00508, pp.1-12 (2020).
- [14] 鶴飼一彦: 眼球運動とその種類, 光学 (Japanese Journal of Optics), Vol.23, No.1, pp.2-8 (1994).
- [15] Yang, Q. Bucci, M and Kapoula K.: The Latency of Saccades, Vergence, and Combined Eye Movements in Children and in Adults, Investigative Ophthalmology & Visual Science, Vol.43, No.9, pp.2939-2949 (2002).
- [16] 国土地理院, GSI HOME PAGE, <https://www.gsi.go.jp> (最終アクセス日: 2022/4/24).